

中国机械工程
China Mechanical Engineering
ISSN 1004-132X,CN 42-1294/TH

《中国机械工程》网络首发论文

题目：	基于变分模态滤波和注意力机制的重载机器人铣削系统颤振辨识方法
作者：	梁志强，陈司晨，杜宇超，刘宝隆，高子瑞，乐毅，肖玉斌，郑浩然，仇天阳，刘志兵
网络首发日期：	2024-07-30
引用格式：	梁志强，陈司晨，杜宇超，刘宝隆，高子瑞，乐毅，肖玉斌，郑浩然，仇天阳，刘志兵．基于变分模态滤波和注意力机制的重载机器人铣削系统颤振辨识方法[J/OL]．中国机械工程. https://link.cnki.net/urlid/42.1294.TH.20240730.1139.002



基于变分模态滤波和注意力机制的重载机器人铣削系统颤振辨识方法

梁志强[1,2]，陈司晨[1]，杜宇超[1]，刘宝隆[1,2]，高子瑞[1]，乐毅[3]，
肖玉斌[4]，郑浩然[1]，仇天阳[1]，刘志兵[1]

（1. 北京理工大学机械与车辆学院　北京　100081；
2. 北京理工大学珠海学院　珠海　519088；
3. 中国空间技术研究院北京卫星制造厂有限公司　北京　100094；
4. 江麓机电集团有限公司　湘潭　411100）

摘要：本文提出了一种定参变分模态滤波、包络滤波和注意力机制网络辨识相结合的重载机器人铣削系统颤振辨识方法。首先，根据变分模态滤波理论，通过合适优选二次惩罚项实现对目标高频非颤振信号分量的剔除；进一步，为了快速辨识当前的加工状态，从信号时域分布出发，结合频域在时域上的映射规律，采用包络滤波方法实现低频主轴转速相关信号分量剔除；最后，构建基于注意力机制网络辨识模型，对预处理后的多时序短时信号片段进行分类以实现加工状态辨识，并开展重载机器人铣削系统加工验证实验。实验分析表明，通过剔除高频非颤振信号和低频主轴转速相关信号分量，再生颤振辨识准确度得到了进一步的提高，辨识准确度可达 98.75%。通过与其它辨识方法对比，本文所构建的重载机器人铣削系统颤振辨识方法可以有效地识别重载机器人铣削系统加工过程中的再生颤振，为后续重载机器人铣削系统颤振在线抑制提供技术支撑。

关键词：机器人铣削；颤振辨识；模态变分滤波；注意力机制
中图分类号：TP242

Research on Chatter Identification Method for Heavy-duty Robotic Milling Based on Variational Mode Filtering and Attention Mechanism

LIANG Zhiqiang[1,2]，CHEN Sichen[1]，DU Yuchao[1]，LIU Baolong[1,2]，GAO Zirui[1]，
YUE Yi[3]，XIAO Yubin[4]，ZHENG Haoran[1]，QIU Tianyang[1]，LIU Zhibing[1]

(1. School of Mechanical Engineering, Beijing Institute of Technology, Beijing 100081;
2. Beijing Institute of Technology, Zhuhai 519088;
3. Beijing Spacecrafts, China Academy of Space Technology, Beijing 100094;
4. Jianglu Machinery & Electronics Group Co. ,Ltd. , Xiangtan 411100)

Abstract: This article introduces a method for detecting chatter in heavy-duty robot milling by integrating variational mode filtering with fixed parameters, envelope filtering, and an attention mechanism network for identification. Initially, variational mode filtering theory is applied to eliminate non-chatter signal components in the high-frequency range by optimally selecting a quadratic penalty. To swiftly determine the current machining condition, the envelope filtering method is employed, leveraging signal time domain distribution and the frequency domain mapping law to remove spindle speed-related signal components in the low-frequency range. Subsequently, a network identification model incorporating an attention mechanism is developed to classify preprocessed multi-temporal short-term signal segments for machining condition identification, followed by verification experiments on heavy-duty robotic milling system. Experimental analysis demonstrates that by eliminating non-chatter signals in the high-frequency

基金项目：基础科研项目（No. DEDPCL），国家自然科学基金（No. 52375400），转化应用项目（No. 2B0188E1 和 D44F9A65）

range and spindle speed-related components in the low-frequency range, the accuracy of regenerative chatter identification is significantly enhanced, achieving an identification accuracy of 98.75%. Compared with alternative identification methods, the proposed method in this paper effectively discerns regenerative chatter during heavy-duty robotic milling processes, thus offering valuable technical support for future online chatter suppression of heavy-duty robotic milling.
Key words: Robot milling; Chatter identification; Variational mode filtering; Attention mechanism

0 引言

六自由度工业机器人因其成本低、灵活性好而被逐渐广泛应用于机械加工。然而，由于机器人结构的刚度较低（一般小于 1 N/μm，比机床小两个数量级），因此在机器人铣削过程中经常可观察到明显的颤振现象[1]。颤振是铣削过程中刀具和工件之间产生的强烈自激振动，会导致加工精度不足、被加工工件表面质量差，甚至损坏加工系统[2-3]，这严重限制了机器人铣削加工应用。为了避免机器人铣削过程中的颤振现象，通常采用保守的加工参数，从而大幅降低生产效率。在过去的几十年里，已经提出了各种颤振预测和控制方法[4,5]。然而，由于机器人稳定性预测模型复杂，难以获得准确的稳定性边界。因此，有效的早期颤振监测方法是机器人铣削在工业中得到广泛应用的可行途径之一。

近年来，许多学者对颤振辨识进行了广泛的研究[6]。Ye 等人[7]计算时域序列的均方根，使用均方根序列的标准差与均值的比值作为变异系数来识别颤振。但简单的时域特征容易受到外界随机波动的干扰导致辨识误判。F. Rumusanu 等[8]基于快速傅里叶变换（Fast Fourier Transform, FFT）计算了频域物理信号的最大幅值与平均值的比值，并以此值来评价处理系统的稳定性。频谱分析是一种直观的信号分量识别方法，但这依赖于充足的信号采样点，在短时信号片段辨识中存在频谱失真的情况。Cao 等人[9]选择小波包变换作为预处理器，利用具有丰富颤振信息的特征包对重构信号实现颤振辨识，但根据不同的加工条件自动选择合适的小波基和分解层数是不方便的。为了克服这一困难，经验模态分解（Empirical mode decomposition, EMD）和集成经验模态分解（Ensemble empirical mode decomposition, EEMD）在颤振辨识中得到了广泛的应用。Liu 等人[10]首先使用 EMD 将信号分解为多个固有模态函数（Intrinsic mode functions，IMFs）。Ji 等人[11]基于改进的 EMD 方法对加速度信号进行分解，并提取重构信号的三维特征向量作为颤振指标。然而，EMD 方法缺乏严谨的理论基础，同时存在模态混叠问题和端点效应。针对这个问题，Dragomiretskiy 和 Zosso[12]提出了变分模态分解（Variational mode decomposition，VMD），它有着完善的理论基础。该方法已被证明比 EMD 具有更好的信号检测和分离效果以及噪声鲁棒性，被认为是最适合信号分解和颤振辨识的方法之一[13,14]。变分模态分解的核心理论是维纳滤波和交替方向乘子法（Alternating Direction Method of Multipliers, ADMM）迭代优化算法，将多分量信号分解为多个准正交子信号分量。Liu 等人[15]提出了一种基于 VMD 和能量熵的颤振辨识方法，研究表明利用峰度自动选择 VMD 参数并计算出包含丰富颤振信息的最佳 IMF 对应的能量熵可用于颤振检测。虽然 VMD 方法可以出色地分解出信号分量，但 VMD 最优分解参数寻优的计算量较大。Kai 等人[13]提出了一种结合 VMD 和模拟退火算法的颤振信息提取方法。Rahul S[16]提出了一种改进的 VMD 方法，该方法与粒子群优化算法相结合来选择 VMD 参数，从而有效地减少了计算量。Chen 等人[17]采用基于相似加工状态类比的机器人铣削加工离线分解参数优选方法。Wang 等人[18]也通过绘制最优参数图的方法实现对机器人加工过程变分模态参数的离线选取。这些改进方法依然建立在 ADMM 迭代收敛过程中，多采样点组成的长时序信号在 ADMM 迭代中需要多次的迭代计算才可以得到实现收敛，所以在参数优选环节上花费了大量时间成

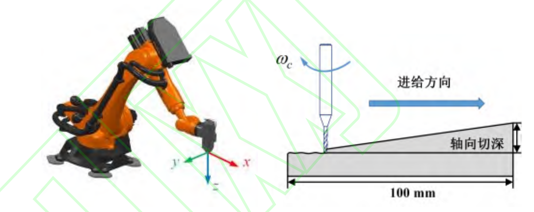
本。这严重限制了机器人早期颤振的在线快速监测。

在基于颤振特征的加工状态辨识方面，目前有多种智能方法被应用于加工状态分类，如支持向量机（Support Vector Machine, SVM）[18-20]、隐马尔科夫模型（Hidden Markov Model, HMM）[21]和深度卷积网络（Deep Convolutional Neural Networks, DCNN）[22]等。籍永建等人[23]通过采用 SVM 方法实现了对于稳定、早期颤振、剧烈颤振、低频颤振以及空载等状态的准确辨识。近年来，对于信号处理得到的颤振特征采用神经网络分类逐渐成为目前的主流方法之一。Janssens 等人[24]首次将卷积神经网络（Convolutional Neural Network, CNN）应用于轴承状态监测。此后，许多学者在故障诊断领域进行了深入的探索[25,26]。注意力机制通过对输入特征采用不同权重，使得包含关键信息的特征不会随着步长的增加而丢失，实现信息增强和信息处理资源的高效分配[27,28]。Zhang 等人[29]采用双路径卷积注意机制和双向门控循环单元进行小样本故障诊断，实现不同工况下的状态准确辨识。邵海东等人[30]构建注意力嵌入的生成对抗网络实现特征学习，用于准确诊断故障模式。

在此基础上，本文从变分模态分解原理中提出一种单步定参变分模态滤波模型滤除高频非颤振分量，减少对铣削颤振信号辨识的影响；进一步通过包络滤波剔除原始信号中的低频主轴转速相关分量；将经过滤波预处理后的多时序时域信号片段作为输入，基于注意力机制模型实现重载机器人斜面铣削加工准确高效状态辨识。

1 重载机器人铣削系统颤振特性

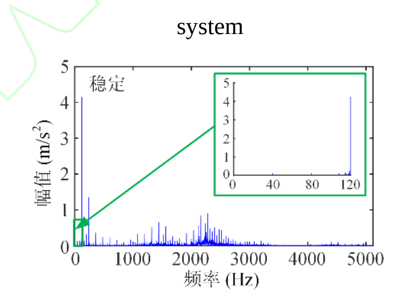
机器人铣削加工系统结构对机器人颤振特性有很大影响，因此，定义机器人的铣削特性对于不同类型的工业机器人至关重要。本研究采用带有 HCS150LG-20KRBT 主轴的 KUKA KR600 R2830 重载工业机器人组成机器人铣削系统并进行铣削加工。为了确定铣削加工过程中的颤振分量特性，如图 1 所示，开展了大量的重载机器人铣削系统加工实验并在主轴端采集加速度信号。图 2 表示在转速为 2400r/min、进给速度为 600mm/min、径向切削深度为 4mm 且轴向切削深度随加工过程逐渐增加时的信号频域信息，加工位姿选择为 P(-77.78°, -61.23°, 100.68°,13.87°,-40.70°,-220.71°)。从图 2 中可以观察到显著的高频再生颤振现象，而在低频区域没有观察到与模态耦合颤振相关的低频颤振。与前后刀齿形成的表面纹理相关，重载机器人铣削系统斜面铣削再生颤振主要发生在铣刀与工件接触位置，且颤振频率分布在重载机器人铣削系统固有频率附近，因此本文重点针对重载机器人铣削系统加工过程中的再生颤振进行研究[2,31,32]。



（a）机器人铣削加工系统　（b）工件加工模型

图1 重载机器人铣削系统模型示意图

Fig.1 Schematic diagram of heavy-duty robot milling system



（a）稳定状态频谱分布

颤振
幅值 (m/s²)
频率 (Hz)

（b）颤振状态频谱分布

图2 重载机器人铣削系统颤振信号特性

Fig.2 Chatter characteristics of the heavy-duty robot milling system

2 变分模态滤波模型

2.1 重载机器人铣削系统斜面铣削信号成分

机器人铣削信号通常被认为由三个分

量组成: $Sp(t)$是包含主轴旋转频率谐波的周期分量，$Sc(t)$是由颤振引起的非周期分量，$Sn(t)$是由环境噪声和测量噪声引起的非周期分量。因此，该模型可以表示为：

$$S(t) = Sp(t) + Sc(t) + Sn(t) \tag{1}$$

当关注于颤振辨识问题时，滤波方法很自然的被认为是提取颤振信号分量的首选方法。从公式(1)中可以看出，需要将主轴转速相关分量滤除，同时高频的非颤振信号也需要着重剔除，这部分信号与颤振相关分量的混叠会影响颤振的辨识。

如图 2 所示，稳定信号的主轴旋转频率谐波分量频域分布集中在低频区域，同时在 2000Hz 左右的高频区域也可以观察到非颤振相关分量。图 3 表示在转速为 2400r/min、进给速度为 600mm/min、径向切削深度为 4mm 时，随着轴向切削深度的线性增加，低频 120Hz 稳定分量和高频非颤振分量幅值的变化情况。其中，高频非颤振分量表示高频范围内主轴旋转频率倍频的信号分量，图中包括 2040Hz、2280Hz 和 2400Hz 频率位置的幅值变化情况。从图中可以看出，低频 120Hz 稳定分量幅值近乎线性增加而高频非颤振分量则基本上属于恒定水平。因此，为了减少高频非颤振分量对高频颤振信息提取的影响，可以基于早期稳定状态信号分量进行滤波。

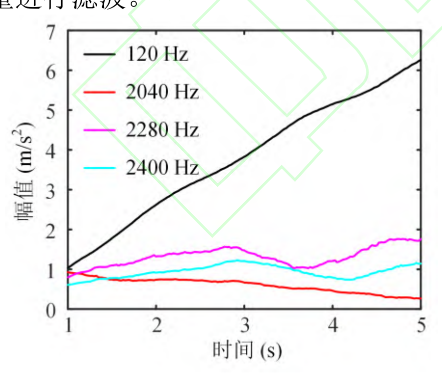


图3 加工信号幅值变化

Fig.3 Changes in signal amplitude during machining

2.2 定参变分模态滤波模型

变分模态分解（VMD）可以将非平稳多模信号分解为一定数量的离散子信号，而子信号在重构输入时具有特定的稀疏性，并且在分解过程中定义模态中心频率。VMD 目前已被广泛用于将信号分解为一系列子信号，其可以表示为：

$$u_k(t) = A_k(t)\cos(\phi_k(t)) \tag{2}$$

其中A_k是子信号分量u_k的幅值，瞬时频率 $\omega_k(t) = \phi_k'(t)$。通过优化约束变分问题的解，可以使所获得的所有模态的带宽之和最小化。因此，变分问题可以表示为：

$$\min_{\{u_k\},\{\omega_k\}} \left\{ \sum_k \left\| \partial t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad s.t. \sum_k u_k = f \tag{3}$$

其中u_k表示通过分解获得的所有模态，表示相应的模态中心频率。然后，使用二次惩罚项α和拉格朗日乘子λ来约束变分问题：

$$L(\{u_k\},\{\omega_k\},\lambda) = \alpha \sum_k \left\| \partial t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), x(t) - \sum_k u_k(t) \right\rangle \tag{4}$$

约束变分问题的解可以通过交替更新u_k，ω_k和λ获取，也被称为交替方向乘子法（ADMM）。其中的子成分优化计算如下：

$$\hat{u}_k^{n+1} \leftarrow \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i^{n+1} + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha\left(\omega - \omega_k^n\right)^2} \tag{5}$$

$$\hat{\omega}_k^{n+1} \leftarrow \frac{\int_0^\infty \omega \left|\hat{u}_k^{n+1}(\omega)\right|^2 d\omega}{\int_0^\infty \left|\hat{u}_k^{n+1}(\omega)\right|^2 d\omega} \tag{6}$$

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau\left(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right) \tag{7}$$

上述算法一直持续到满足收敛条件：

$$\left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|_2^2 / \left\| \hat{u}_k^n \right\|_2^2 < \varepsilon \tag{8}$$

通过适当的k、α、τ和ε设置，可以将原始信号分解为多个包括不同信号分量的子信号。该方法已被证明在从加工信号中提取颤振信息方面是有效的。其中，噪声容忍度τ和收敛容忍度ε主要影响迭代速度，而k和α对信号分解质量有显著的影响，因此在颤振辨识中开展了广泛的研究。

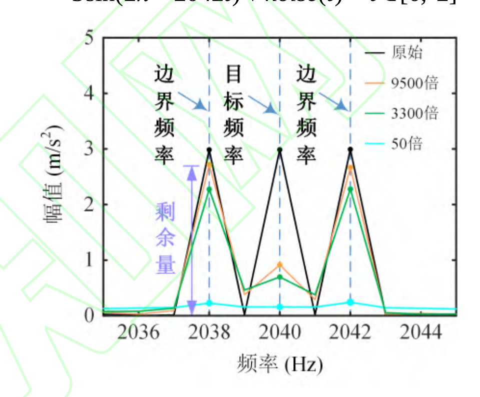
然而正如前言所述，大多数方法基于变分模态方法提取颤振辨识子信号时会遇到自适应参数选择耗时较大问题。同时，ADMM的迭代收敛原理使得时间成本不可避免。由于稳定状态下的高频非颤振能量在进入稳定铣削状态后基本保持恒定，本文提

出了一种基于变分模态分解原理的定参变分模态滤波模型以实现对目标频率分量信号的滤除。具体来说，通过选取合适的二次惩罚项α进行变分模态滤波实现类似于带阻滤波的信号处理效果，剔除特定的高频非颤振频率信号分量。相比于传统VMD方法，该模型采用更高的二次惩罚项α，且直接基于稳定信号频谱选取信号分解个数k和二次惩罚项α，无需进行参数优选[15]。

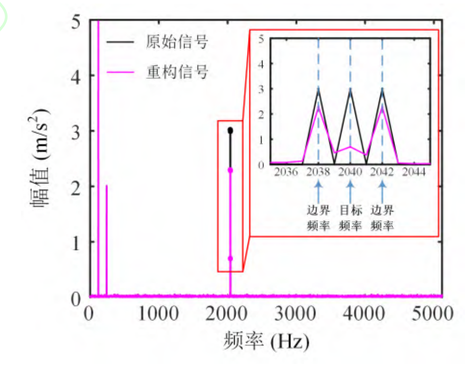
由于图2中的高频非颤振分量信号频率位置与颤振频率及其谐波位置接近，此时定参变分模态滤波模型所选取的二次惩罚项α的值远大于传统VMD信号分解的值[15]，往往是常用VMD模型的数千倍。为了求解合适的二次惩罚项α实现频率窄带分量剔除，建立如公式(9)所示的仿真信号。为了观察过滤窄带的效果，在2038Hz位置设置与过滤频率2040Hz相同幅值的信号分量；120Hz和240Hz的信号分量则代表着稳定状态下的主轴旋转频率分量。从图4(a)可以观察到，随着二次惩罚项α的增加，变分模态滤波后的目标频率（2040Hz）剩余信号能量会逐渐增加，这说明过大的二次惩罚项α会导致目标频率信号剔除效果下降；但过小的二次惩罚项α又会导致过滤频带较宽，在剔除目标频率信号分量的同时也剔除了目标边界频率分量，从而影响可能存在的颤振信息的提取。因此，为了尽可能保留目标边界频率分量并剔除目标频率分量，以目标边界频率幅值经过变分模态滤波后的剩余量与目标频率幅值剩余量的比值取最大值时的二次惩罚项α值作为二次惩罚项α值的最优值，其中边界频率间隔为2Hz。如图4(b)所示，目标频率为2040Hz，则以2038Hz信号分量的剩余水平和2040Hz信号分量的剩余水平的比值作为二次惩罚项α优化选择的依据。当目标剔除频率分量对应的二次惩罚项α选择为f_s的3300倍时，图4(c)中目标边界频率幅值（2038Hz）的剩余量为2.275，目标频率（2040Hz）幅值剩余量为0.698，此时两者的比值最大，因此对目标频率的信号剔除效果最佳（f_s为信号采样频率）。通过仿真信号离线提前获取不同目标频率幅值下的最佳二次惩罚项α选值，优化选取结果如图5所示，越大的目标频率信号分量幅值所需对应的二次惩罚项α也越大。同时，选择幅值大于10%最大稳定分量幅值的频率位置作为变分模态滤波的初模态中心频率，其数量作为目标频率个数k。

由于直接基于当前信号的频谱特征进行目标频率个数k和对应二次惩罚项α的选择，避免了传统VMD方法所需要进行的参数优选，为变分模态滤波方法的在线应用提供的可能。对于3280组短时信号长度为128的信号片段进行滤波处理，计算滤波处理的平均耗时为8.9 ms。

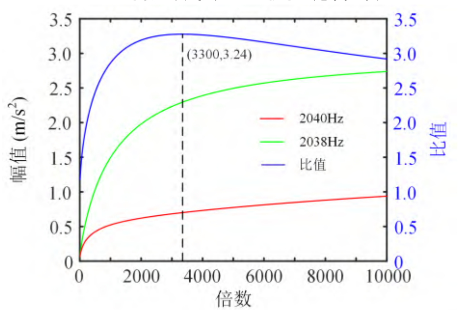
$$
\begin{aligned}
x_1(t) = {} & 5\sin(2\pi\times 120t) + 2\sin(2\pi\times 240t) + \\
& 3\sin(2\pi\times 2038t) + 3\sin(2\pi\times 2040t) + \\
& 3\sin(2\pi\times 2042t) + noise(t) \quad t\in[0,\ 2]
\end{aligned}
\tag{9}
$$



（a）不同二次惩罚项α下的滤波效果



（b）目标频率分量最佳滤除效果



（c）二次惩罚项α最优选择

图4 变分模态目标频率分量滤除

Fig.4 Target frequency component filtering under

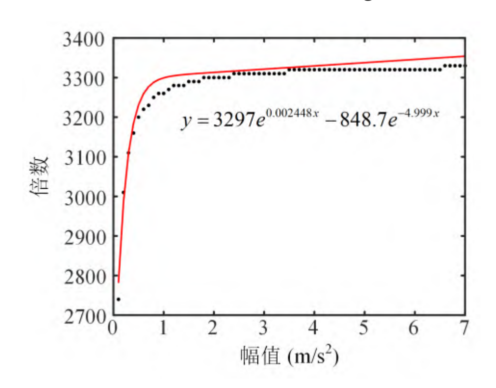


图5 二次惩罚项α选取原则

Fig.5 Selection principle of the quadratic penalty α

3 短时时域信号特征

3.1 包络滤波

如图6所示，从频域角度看，实际加工颤振时的信号可以认为是主轴旋转频率分量与高频颤振频率分量融合的结果。主轴旋转频率分量和高频颤振频率分量分别对应于调频中的信息信号和载波信号，融合后的信号可以看作调制信号。从时域角度看，高频颤振频率分量会沿着低频的主轴旋转频率分量分布。因此，重载机器人铣削系统高频再生颤振频率分布可以在时域信号上观察到对应的分布特性，在此基础上提出包络滤波方法，从时域上快速提取高频再生颤振频率信息。

为了分析包络处理的参数选择和滤波效果，构建如公式(10)所示的加工过程仿真信号。包络法的核心参数是希尔伯特FIR滤波器的长度fl。由于再生颤振频率分布在2000Hz以上，信号采样频率为10240Hz，因此fl的选择如公式(11)所示。

$$x_2(t)=\begin{cases}(5+0.6t)\sin(120\pi t)\\+(2-0.25t)\sin(240\pi t)+noise(t) & t\in[0,\ 3)\\ \\(5+0.6t)\sin(120\pi t)+(2-0.25t)\sin(240\pi t)\\+(3t-9)\sin(2132\pi t)+(2.5t-7.5)\sin(2252\pi t) & t\in[3,\ 5)\\+(2t-6)\sin(2372\pi t)+noise(t)\\ \\8\sin(120\pi t)+0.75\sin(240\pi t)\\+6\sin(2132\pi t)+5\sin(2252\pi t) & t\in[5,\ 7]\\+4\sin(2372\pi t)+noise(t)\end{cases} \tag{10}$$

$$fl=\frac{1}{2000}\times 10240=5.12\approx 5 \tag{11}$$

当选取fl为5时，如图7所示，包络后的根据上下包络线提取高频信息，如公式(12)所示。其中，D_{up}表示上包络线数据，D_{lo}表示下包络线数据，D表示原信号数据，D_{d}表示包络滤波后的数据。图7中，经过包络滤波处理，从时域和频域上都可以很明显地观察到信号中的低频分量在很大程度上被剔除，仅保留高频分量。由于仿真信号$x_2(t)$模拟的是剔除高频非颤振分量内的信号，因此可以认为包络滤波处理可以实现颤振相关信号的时域提取。相比于以傅里叶变化为基础的频谱分析，包络滤波处理没有充足采样的限制且操作方便、时间成本小，更适用于短时时域片段处理。

$$D_{\mathrm{d}}=D-\frac{(D_{\mathrm{up}}+D_{\mathrm{lo}})}{2} \tag{12}$$

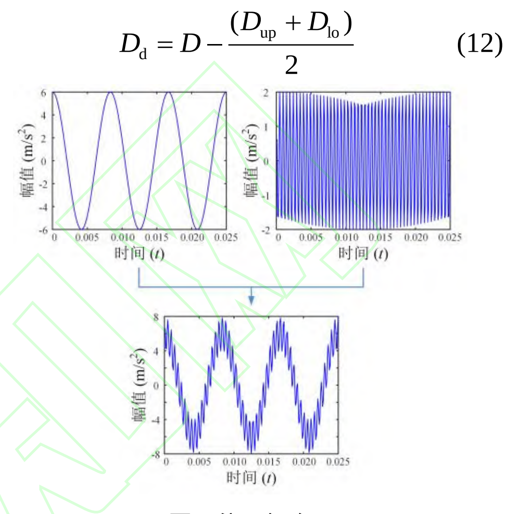


图6 信号耦合

Fig.6 Signal modulation

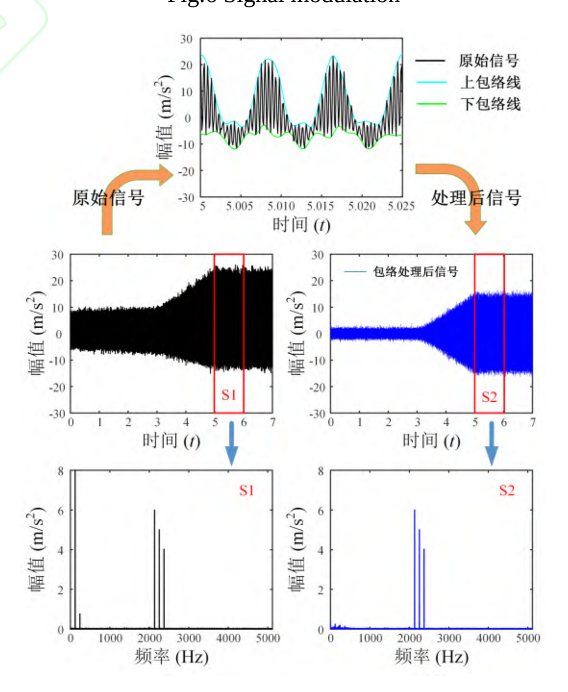
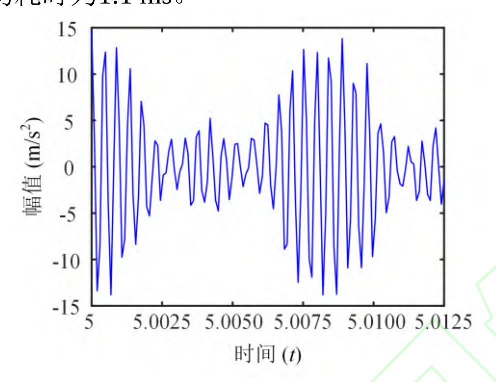


图7 包络滤波效果

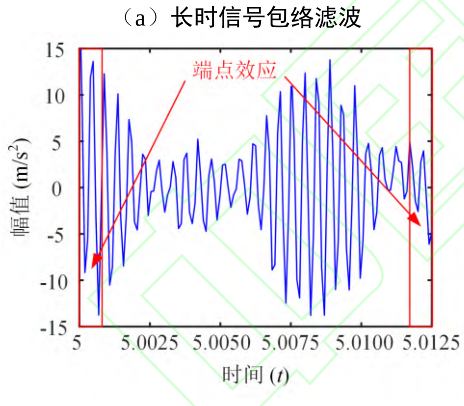
Fig.7 Envelope filtering effect

由于最终的分析对象为短时信号片段，

因此需要分析公式(12)所引起的端点效应[33]。采用公式(12)分别对长时序信号进行包络滤波处理后截取的短时序信号片段，如图8(a)所示；直接对短时序信号片段进行包络滤波处理，如图8(b)所示。此时图8(a)中不存在端点效应，而图8(b)表示存在端点效应时的包络滤波处理效果。从对比结果可以看出，由于端点效应的影响，短时序信号片段的前后末端相较于图8(a)存在差异，但整体结果趋势相同，因此可以用于短时序信号片段处理。对于3280组短时信号长度为128的信号片段进行滤波处理，计算滤波处理的平均耗时为1.1 ms。



（a）长时信号包络滤波



（b）短时信号包络滤波

图8 短时信号包络滤波可行性

Fig.8 Feasibility of short-signal envelope filtering

3.2 多时序短时时域信号特征

根据定参变分模态定向剔除的滤波分析中可以得到，这样的滤波方法可以在很大程度上减少对应目标频率的信号分量，但无法实现完全滤除，这就意味着变分模态滤波和包络滤波使得实际加工过程总的稳定信号依然包含少量的高频颤振无关分量，只是其对应的能量较少。

考虑到稳定信号在剔除高频非颤振信号后的高频分布能量水平低且分布较为随机，而颤振信号则存在周期性的高频信号分量。那么在包络处理后的短时信号会在时域和频域上存在明显的差异。因此短时信号片段单元包含的采样点为128，即短时时域信号片段时长为0.0125s。

由于铣削加工是一个时序过程，因此需要充分考虑上一个时间片段和下一个时间片段的状态信息来预测当前状态的分类结果以突出时序特点。同时，多短时片段可以规避颤振中的节拍效应[34]，能够提高加工状态辨识的准确性。因此，选取8个短时信号片段单元组成一个时长为0.1s的多时序短时信号片段作为后续颤振预测模型的输入。

4 基于注意力机制的颤振辨识模型

4.1 双层卷积层

卷积层通过卷积核在输入数据的局部区域上提取相应的特征[35]。将一维短时时域信号特征利用卷积神经网络（CNN）进行特征提取，每个输入数据片段的输出如公式(13)所示：

$$c_i = f(\boldsymbol{W}_\mathrm{c} \otimes x_i + b_\mathrm{c}) \quad c_i \in \mathbb{R}^{N_{sub}} \tag{13}$$

其中，$\boldsymbol{W}_\mathrm{c}$和$b_\mathrm{c}$分别表示卷积核的权重矩阵和偏置量。$f$表示激活函数，这里使用Leaky ReLU激活函数。符号$\otimes$表示卷积，定义输入为$x_{j:j+h-1} = [x_j, x_{j+1}, x_{j+2}, \ldots, x_{j+h-1}]$，$x_{j:j+h-1} \subseteq x_i$的局部区域与卷积核$\boldsymbol{W}_\mathrm{c}$的逐元素乘积。通过两层卷积后提取的特征如公式(14)所示：

$$C = [c_1, c_2, c_3, \ldots, c_M] \in \mathbb{R}^{M_{sub} \times M} \tag{14}$$

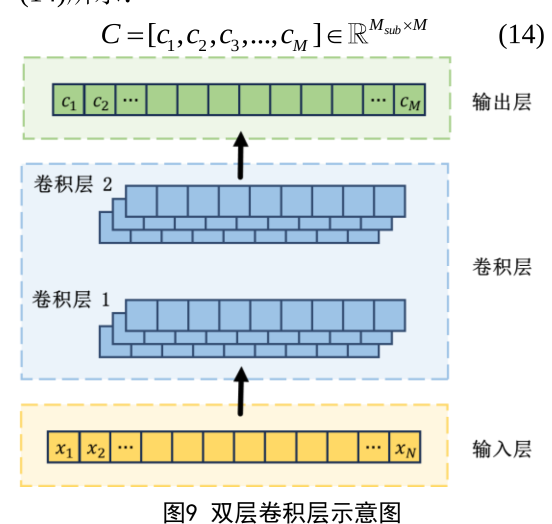


图9 双层卷积层示意图

Fig.9 Schematic diagram of double CNN

4.2 注意力层

采用注意力机制突出输入数据中不同特征对输出结果的影响程度，使得算法自主学习调整输入数据中的关键特征，提高模型的效率和性能，如图10所示。注意力层的计算方法如公式(15)所示。

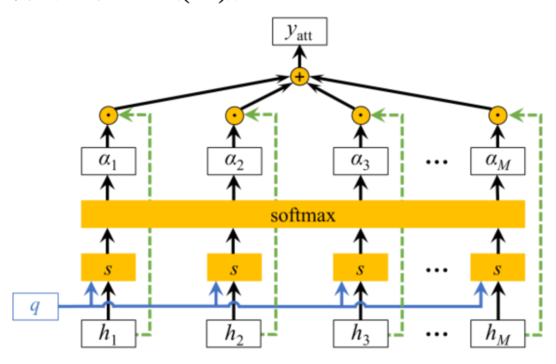


图10 注意力机制示意图

Fig.10 Schematic diagram of attention mechanism

$$\alpha_n = p(z=n\,|\,H,q) = \mathrm{softmax}(s(h_n,q)) = \frac{\exp(s(h_n,q))}{\sum_{j=1}^{N}\exp(s(h_j,q))} \tag{15}$$

其中 $H=[h_1,h_2,h_3,...,h_M]\in\mathbb{R}^{M_{sub}\times M}$ 表示输入向量，$z\in[1,M]$表示注意力变量，q表示查询向量。$s(h_n,q)$表示注意力评分函数，用于计算每个输入向量与查询向量之间的相关性。α_n表示注意力权重，是在给定H和q的情况下选择第i个输入向量的概率。使用不同的注意力评分函数会得到不同的注意力机制，本文采用的注意力评分函数如公式(16)所示：

$$s(H,q)=q^{\mathrm{T}}H \tag{16}$$

其中，q表示查询向量。获取每个输入向量的注意力权重后，通过公式(17)得到注意力层最终的输出。

$$y_{att}=\sum_{n=1}^{M}\alpha_n h_n \tag{17}$$

在多时序短时信号片段加工状态辨识中，以两层卷积后提取的特征C作为注意力层的输入H，以卷积层中第一层的输出结果R作为注意力层的查询向量q，构建基于注意力机制的颤振预测模型，如图11所示。中再机器人铣削系统颤振辨识模型通过短时信号判断当前加工状态为稳定加工状态或颤振加工状态，因此注意力层的输出为加工状态分类结果。

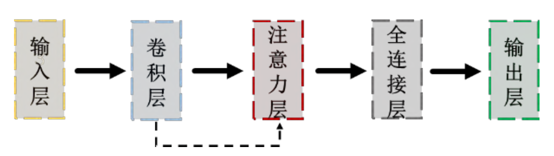


图11 基于注意力机制的颤振辨识模型

Fig.11 Chatter identification model based on attention mechanism

5 重载机器人铣削系统颤振辨识

5.1 实验设置

为了便于在铣削过程中观察到稳定铣削状态过渡到颤振状态，本研究在KUKA KR600重载工业机器人上开展了斜面铣削实验。在铣削实验中使用了直径为10 mm的硬质合金铣刀，该铣刀的齿数为3且刀具悬长为61 mm，刀具螺旋角为45°。工件为5A06铝合金，尺寸为100 mm×50 mm×30 mm。加速度信号由加速度传感器（INV9822）测量，加速度传感器布置于机器人末端高速主轴处，其灵敏度为10.355mV/ms^{-2}，采样频率f_s设置为10.24 kHz。INV3062T四通道信号采集装置用于对信号进行采样。整个铣削设置为无润滑条件下的顺铣，如图12所示。

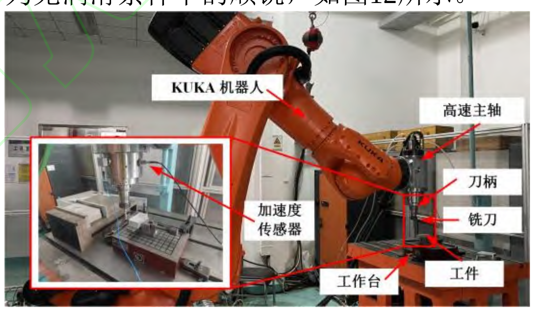


图12 重载机器人铣削系统加工实验

Fig.12 Heavy-duty robot milling experiment

为验证所提出的颤振辨识算法的有效性，采集加工过程中的加速度信号并开展重载机器人铣削系统颤振在线辨识验证实验，验证实验的实验参数如表1所示，加工位姿选择与第1节中的P位姿相同。其中，表1中的轴向切深“3-8”表示切深从3mm逐渐增加至8mm。

表1 重载机器人铣削实验加工参数表

Tab.1 The parameter table of heavy-duty robot milling

序号	主轴转速/(r/min)	进给速度/(mm/min)	径向切深/mm	轴向切深/mm
1	2400	300	3	3-8
2	2400	600	3	3-8

3	2400	300	4	2-7
4	2400	600	4	2-7
5	3000	600	3	0-5
6	3000	600	4	0-5
7	3600	600	3	3-8
8	3600	300	4	1-6
9	3600	600	4	0-5
10	4800	600	3	1-5
11	4800	300	4	0-5
12	4800	600	4	0-5
13	6000	300	4	0-5
14	6000	600	4	0-5
15	7200	300	4	0-5
16	7200	600	4	0-5
17	8000	600	4	0-5

5.2 短时时域信号特征准确度

根据第4章的注意力机制的颤振预测模型，短时时域信号片段作为辨识模型的输入，为了分析滤波预处理的必要性，对比定参变分模态定向剔除和包络滤波前后的重载机器人铣削系统加工状态辨识准确度。在重载机器人铣削系统加工过程可以分为稳定状态和颤振状态，因此辨识模型的输出为二分类问题。为了验证模型的泛化性，将每组参数下整理得到的短时信号片段随机整合在数据集内。其中，稳定样本数量为4130组多时序短时信号片段，颤振样本数量为3490组多时序短时信号片段，在组成的数据集中训练集和测试集的占比分别为80%和20%。基于注意力机制的颤振网络辨识模型中的具体参数如表2所示。其中K、N、S分别表示卷积核的大小、个数和滑动步长。

表2 模型参数

Tab.2 Model parameters

参数	数值
短时片段长度	128
多时序片段数量	8
卷积层一	K=3×1, N=16, S=1
卷积层二	K=3×1, N=32, S=1
学习率	0.0005

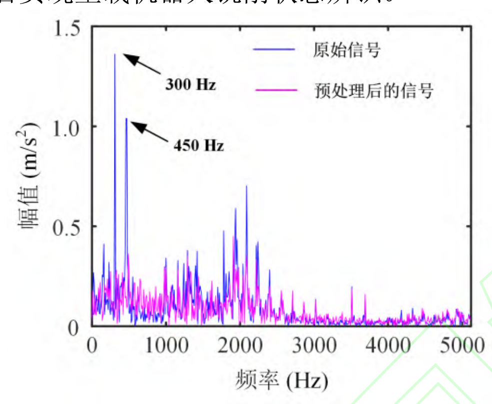
图13为表1中案例5下的加工信号在进行变分模态滤波和包络滤波后的多时序短时信号片段的频谱分布情况，从图13(a)中可以看出，稳定信号的整体信号分量经过信号预处理处于一个很低的能量水平，这也符合当前不存在颤振相关分量的特点；相比之下，颤振信号经过信号预处理后，信号中的颤振分量依然存在且处于绝对主导地位。这说明经过变分模态滤波和包络滤波预处理后的时域信号具有明显的颤振特性。

采用基于注意力机制的颤振预测模型测试结果如图14所示。当未进行定参变分模态滤波和包络滤波时，采用注意力机制的颤振预测模型可以实现97.11%的分类准确度，可以看出注意力机制模型在颤振辨识方面的优势。通过不太复杂的网络模型构建和对多时序短时信号片段进行辨识，既减少模型的学习时间又提高了辨识的速度。进一步，在进行信号预处理后，此时的状态辨识准确率可达98.75%。由此可见，定参变分模态滤波和包络滤波可以提高信号片段对颤振的辨识度，其中，16个多时序短时时域信号片段被误判为稳定加工状态，3个多时序短时时域信号片段被误判为颤振加工状态。这可能是因为部分参数的颤振状态下存在节拍效应，此时对应的多时序短时时域信号片段与稳定状态下的信号较为相似，从而造成误判。

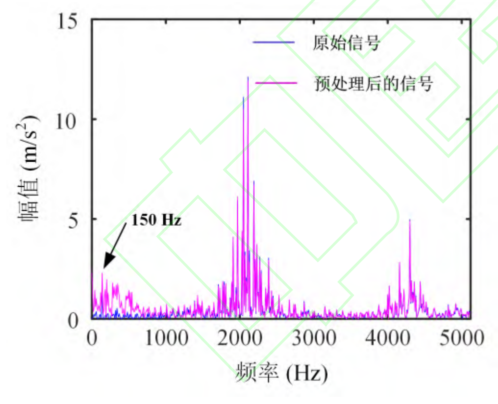
SVM作为传统的分类模型，在机器人颤振辨识领域也得到了广泛的应用[18,23]，为了验证所构建的信号处理方法和辨识网络的优越性，采用的SVM模型[18]进行对比。其中利用基于径向基函数(RBF)的SVM分类模型实现振动状态的识别。对于SVM模型采用未进行信号预处理的原始数据集进行训练，采用测试集进行模型验证，最终得到的分类准确度如图15所示。从图15中可以看出，SVM模型的辨识准确度可达95.34%，也可以实现对稳定信号的准确分类，但对于颤振信号，其准确度仅为89.83%。上述结果表明，本文提出的定参变分模态滤波和包络滤波方法，结合基于注意力机制的颤振预测模型可以更加准确地辨识出重载机器人铣削系统加工状态，验证了本文方法的优越性。

为了对比所提出的基于注意力机制的颤振辨识模型和SVM模型的时间运行效率，对测试集中的1524个片段长度为0.1s的样本进行辨识。其中，基于注意力机制的颤振辨

识模型的总耗时为0.26s，SVM模型的总耗时为0.74s，由此可见，所提出的基于注意力机制的颤振辨识模型具有很好的在线应用可行性。进一步研究本文方法的在线颤振辨识可行性，在时序模型中，对于0.1s的信号片段，变分模态滤波方法通过对8组由128采样点（0.0125s）组成的短时信号片段拼接得到0.1s信号片段的滤波处理结果，进而采用所提出的基于注意力机制的颤振辨识模型对该0.1s信号进行辨识，结合上述研究，基于变分模态滤波和注意力机制的重载机器人铣削系统颤振辨识方法平均需要0.08s左右实现重载机器人铣削状态辨识。



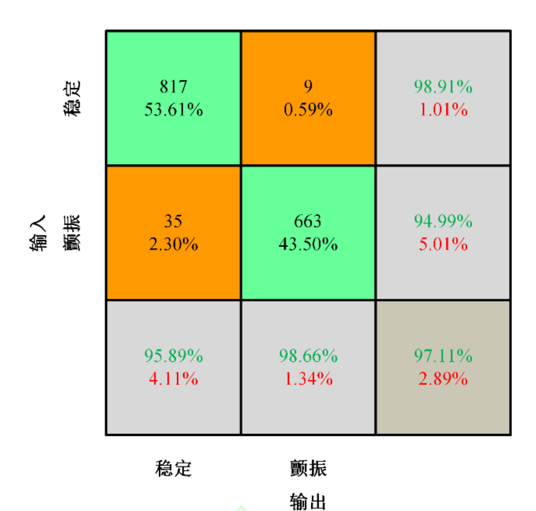
（a）稳定多时序短时信号频谱



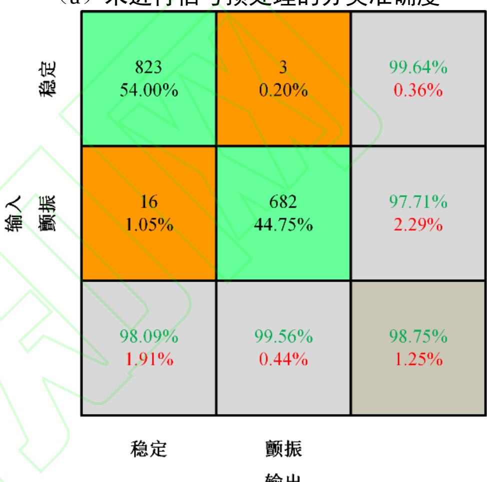
（b）颤振多时序短时信号频谱

图13 信号预处理效果（案例5）

Fig.13 Signal preprocessing effect (Case 5)



（a）未进行信号预处理的分类准确度



（b）信号预处理后的分类准确度

图14 基于注意力机制的颤振辨识模型测试结果

Fig.14 Test results of chatter identification model based on attention mechanism

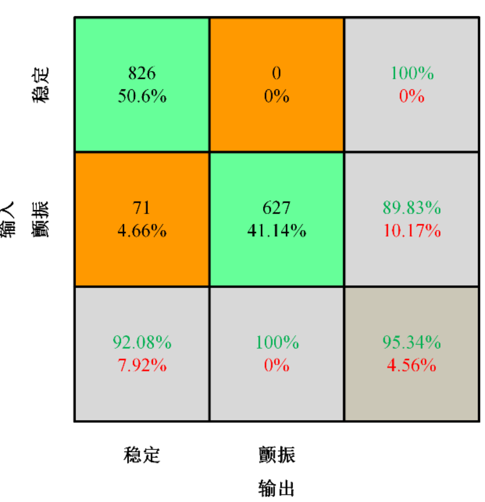


图15 SVM模型测试结果

Fig.15 Test results of SVM model

6 总结

重载机器人铣削系统在加工过程中由于加工参数的不当选择会引起严重的再生颤振，本文提出了一种定参变分模态滤波和包络滤波相结合的信号预处理方法对高频非颤振信号分量和低频主轴转速相关信号分量进行滤除后可以从短时时域信号中提取颤振相关信号。通过将多时序短时信号片段作为信号特征输入所构建的基于注意力机制的颤振预测模型，辨识准确率达到98.75%，验证了所提出方法的有效性和可行性，为后续重载机器人铣削系统颤振在线抑制提供技术支撑。

参考文献

[1] Quintana G, Ciurana J. Chatter in machining processes: A review[J]. The International Journal of Machine Tools and Manufacture, 2011, 51 (5): 363–376.

[2] 王涛，高雪峰，祝景萍，等. 机器人纵扭超声铣边颤振在线监测方法[J]. 航空学报，2023, 44: 1-11.
Wang T, Gao X, Zhu J P, et al. Chatter online monitoring of robotic longitudinal-torsional edge trimming[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44: 1-11.

[3] 孙朝阳，彭芳瑜，唐小卫，等. 基于自适应变分模态分解与功率谱熵差的机器人铣削加工颤振类型辨识[J]. 机械工程学报，2023，59: 1-11.
Sun Z, Peng F, Tang X, et al. Robotic milling chatter types detection based on adaptive variational mode decomposition and difference of power spectral entropy[J]. Journal of Mechanical Engineering, 2023, 59: 1-11.

[4] Mousavi S, Gagnol V, Bouzgarrou BC, Ray P. Dynamic modeling and stability prediction in robotic machining [J]. International Journal of Machine Tools & Manufacture, 2017, 88(9-12): 3053-3065.

[5] 梁志强,石贵红,杜宇超等. 考虑主轴-刀柄结合面特性的机器人铣削系统刀尖频响预测研究 [J]. 中国机械工程, 2023, 34 (01): 2-9.
Liang Z, Shi G, Du Y, et al. Research on Tool Tip Frequency Response Prediction of Robot Milling System Considering Characteristics of Spindle-toolholder Interface[J]. China Mechanical Engineering, 2023, 34 (01): 2-9.

[6] Siddhpura M, Paurobally R. A review of chatter vibration research in turning[J]. International Journal of Machine Tools & Manufacture, 2012, 61: 27-47.

[7] Ye J, Feng P, Xu C, et al. A novel approach for chatter online monitoring using coefficient of variation in machining process[J]. International Journal of Advanced Manufacturing Technology, 2018, 96: 287-297.

[8] Rumusanu F, Constantin GR, Marinescu IC, et al. Development of a stability intelligent control system for turning [J]. International Journal of Advanced Manufacturing Technology, 2013, 64:643–657

[9] Cao H, Lei Y, He Z. Chatter identification in end milling process using wavelet packets and Hilbert-Huang transform[J]. International Journal of Machine Tools & Manufacture, 2013, 69: 11-19.

[10] Liu H, Q. Chen Q, Li B, et al. On-line chatter detection using servo motor current signal in turning[J]. Science China-Technological Science, 2011, 54 (12): 3119-3129.

[11] Ji Y, Wang X, Liu Z et al. Early milling chatter identification by improved empirical mode decomposition and multi-indicator synthetic evaluation[J]. Journal of Sound Vibration, 2018, 433: 138-159.

[12] Dragomiretskiy K, Zosso D. Variational Mode Decomposition[J]. IEEE Transactions on. Signal Processing, 2014, 62 (3): 531-544.

[13] Yang K, Wang G, Dong Y, et al. Early chatter identification based on an optimized variational mode decomposition[J]. Mechanical Systems and Signal Processing, 2019, 115: 238-254.

[14] Wang Y, Markert R, Xiang J, et al. Research on variational mode decomposition and its application in detecting rub-impact fault of the rotor system[J]. Mechanical Systems and Signal Processing, 2015, 60-61: 243-251.

[15] Liu C, Zhu L, Ni C. Chatter detection in milling process based on VMD and energy entropy[J]. Mechanical Systems and Signal Processing, 2018,105: 169-182.
[16] Rahul S, Sunitha R. Dominant Electromechanical Oscillation Mode Identification using Modified Variational Mode Decomposition[J]. Arabian Journal for Science and Engineering, 2021, 46 (10): 10007–10021.
[17] Chen Q, Zhang C, Hu T, et al. Online chatter detection in robotic machining based on adaptive variational mode decomposition[J], The International Journal of Advanced Manufacturing Technology, 2021, 117(1-2): 555-577.
[18] Wang Y, Zhang M, Tang X, et al. A kMap optimized VMD-SVM model for milling chatter detection with an industrial robot[J]. Journal of Intelligent Manufacturing, 2022, 33(5): 1483-1502.
[19] Chen Y, Li H, Hou L, et al. An intelligent chatter detection method based on EEMD and feature selection with multi-channel vibration signals[J]. Measurement, 2018, 127: 356-365.
[20] Wang Y, Bo Q, Liu H, et al. Mirror milling chatter identification using Q-factor and SVM[J]. International Journal of Advanced Manufacturing Technology, 2018, 98(5-8): 1168-1177.
[21] Zhang L C ,Yue X ,Jiang T Y , et al. A Hybrid Approach of ANN and HMM for Cutting Chatter Monitoring [J]. Advanced Materials Research, 2010, 905 (97-101): 3225-3232.
[22] Batihan S, Ugur M G, Murat A O, et al. A novel chatter detection method for milling using deep convolution neural networks[J]. Measurement, 2021, 182.
[23] 籍永建,姚利诚. 机器人铣削加工颤振自适应识别方法研究 [J]. 中国机械工程, 2023, 34 (18): 2165-2176.
Ji Y, Yao L. Research on Self-adaptive Chatter Recognition Method for Robotic Milling[J]. China Mechanical Engineering, 2023, 34 (18): 2165-2176.
[24] Janssens O, Slavkovikj V, Vervisch B, et al. Convolutional Neural Network Based Fault Detection for Rotating Machinery [J]. Journal of Sound and Vibration, 2016, 377 331-345.
[25] Huang T, Fu S, Feng H, et al. Bearing Fault Diagnosis Based on Shallow Multi-Scale Convolutional Neural Network with Attention [J]. Energies, 2019, 12 (20).
[26] Pan H, He X, Tang S, et al. An Improved Bearing Fault Diagnosis Method using One-Dimensional CNN and LSTM [J]. Strojniški vestnik - Journal of Mechanical Engineering, 2018, 64(7-8):443-452.
[27] Bahdanau D, Cho K, Bengio Y. Neural Machine Translation by Jointly Learning to Align and Translate. [J]. CoRR, 2014, abs/1409.0473.
[28] Yang Z, Zhang J, Zhao Z, et al. Interpreting network knowledge with attention mechanism for bearing fault diagnosis [J]. Applied Soft Computing Journal, 2020, 97 (PB): 106829.
[29] Xin Z, Chao H, Yanping L, et al. Fault diagnosis for small samples based on attention mechanism [J]. Measurement, 2022, 187.
[30] 邵海东,李伟,刘翊,等. 时变转速下基于双阈值注意力生成对抗网络和小样本的转子-轴承系统故障诊断 [J]. 机械工程学报, 2023, 59 (12): 215-224.
Shao H, Li W Liu Y, et al. Fault Diagnosis of Rotor-bearing System under Time-varying Speeds by Using Dual-threshold Attention-embedded GAN and Small Samples [J]. Journal of Mechanical Engineering, 2023, 59 (12): 215-224.
[31] Huseyin C, Erdem O, D. N S. Can mode coupling chatter happen in milling? [J]. International Journal of Machine Tools and Manufacture, 2021, 165 103738-.
[32] Cordes M, Hintze W, Altintas Y. Chatter stability in robotic milling [J]. Robotics and Computer Integrated Manufacturing, 2019, 55 11-18.
[33] Cao H, Zhou K, Chen X. Chatter identification in end milling process based on EEMD and nonlinear dimensionless indicators [J]. International Journal of Machine Tools and

Manufacture, 2015, 92 52-59.
[34] Sun Y, He J, Ma H, et al. Online chatter detection considering beat effect based on Inception and LSTM neural networks [J]. Mechanical Systems and Signal Processing, 2023, 184.
[35] 胡茑庆,陈徽鹏,程哲等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法 [J]. 机械工程学报, 2019, 55 (07): 9-18.
Hu N, Chen H, Cheng Z, et al. Fault Diagnosis for Planetary Gearbox Based on EMD and Deep Convolutional Neural Networks[J]. Journal of Mechanical Engineering, 2019, 55 (07): 9-18.

作者简介：梁志强，男，1984 年出生，博士，教授，博士生导师。主要研究方向为先进切削磨削抛光技术、机器人加工、微细加工、微细刀具设计与制造、超声加工、特种机床与装备制造技术。

E-mail：liangzhiqiang@bit.edu.cn

杜宇超(通信作者)，男，1992 年出生，北京理工大学博士后。主要研究方向为机器人铣削、微细刀具设计与制造。

E-mail：dycfelix@163.com